

- Emilio Del Moral Hernandez

Slides comentados  
Prof. Emilio Del Moral Hernandez

18:22 Role para ver detalhes

© Prof. Emilio Del Moral Hernandez

## Temas da sexta semana c/ Prof. Emilio

28

### 2ª aula da 6a semana ... 15 de abril

(vamos abordar o que que havia sido planejado para a aula de 13 de abril)

**#11 (13/abril – 2ªf)** Soluções em reconhecimento e em regressão empregando dois estágios: primeiro estágio para extração de características / extração de medidas e para a redução de dimensionalidade + segundo estágio MLP como reconecedor / regressor genérico; técnicas diversas de extração de características em projetos concretos. Extensões de análise harmônica (Fourier) para a extração de características; conceitos básicos em análise tempo-frequência. PCA - Análise de Componentes Principais como extrator de características.

**#12 (15/abril – 4ªf)** Aprofundando a conexão dos temas que aprendemos com o Deep Learning; conexão com redes neurais redutores de dimensionalidade. Apanhado das temáticas aprendidas e troca de ideias sobre a “A4 de consulta” + sessão de dúvidas p/ P1;

*22 de abril (4ªf) e 27 de abril (2ªf): P1 em PSI3471 – ou seja, dentro da semana de provas P1 da Elétrica (em 20 de abril, pela ponte de Tiradentes, não há aula na 2ª feira)*

© Prof. Emilio Del Moral Hernandez

29

## Próximos tópicos PSI3471-2020 ...

recordando

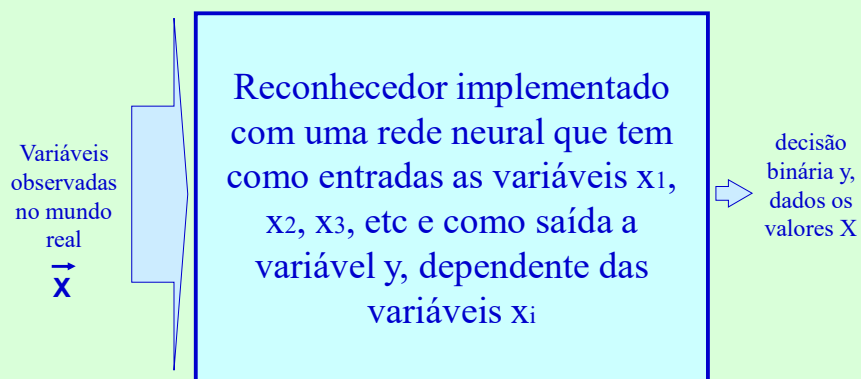
- Soluções em reconhecimento e em regressão em dois estágios
- 1º estágio como extrator de características / extrator de medidas
- 1º estágio como redutor de dimensionalidade de X após sua reescrita
- Técnicas de extração de características / redução de dimensionalidade (PCA e outros)

29

© Prof. Emilio Del Moral Hernandez

## Detector / reconhecedor multivariado

47

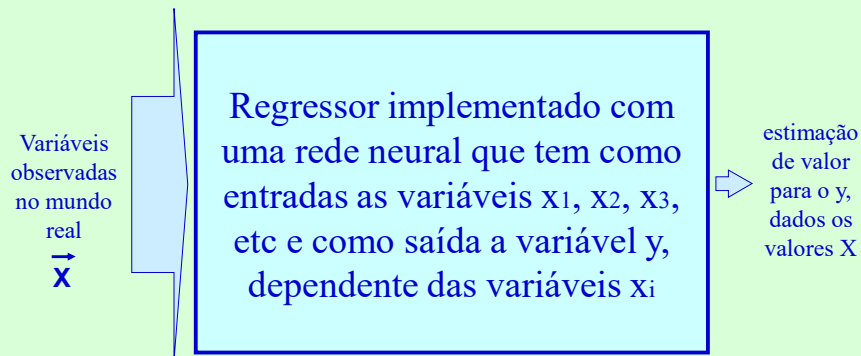


© Prof. Emilio Del Moral Hernandez

47

## Regressor multivariado

48



© Prof. Emilio Del Moral Hernandez

48

Em vários projetos de regressão e reconhecimento (embora não em todos) há a necessidade de uma solução em 2 estágios

51

Um primeiro responsável por extração de características / extração de medidas mais relevantes dos objetos "X" brutos, medidas essas normalmente específicas para cada aplicação, e ...

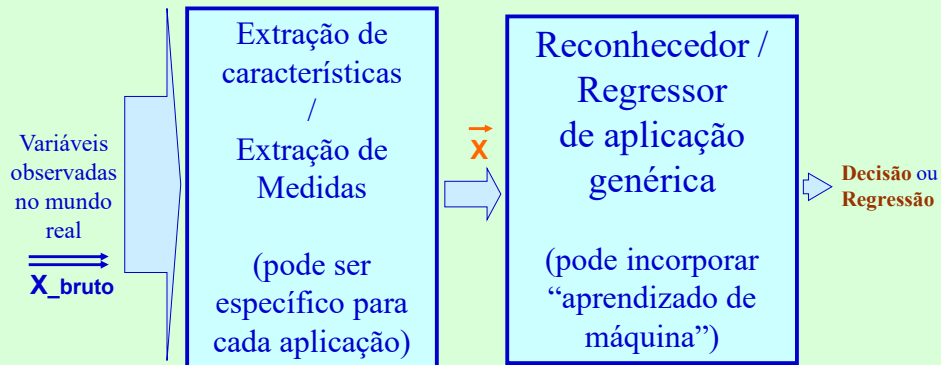
Um segundo estágio atuando sobre o vetor com essas diversas medidas, e que emprega alguma técnica para a regressão / identificação de padrões, independente da aplicação, como é o caso de redes neurais artificiais

© Prof. Emilio Del Moral Hernandez

51

## Elaborando uma Solução em dois estágios ....

53

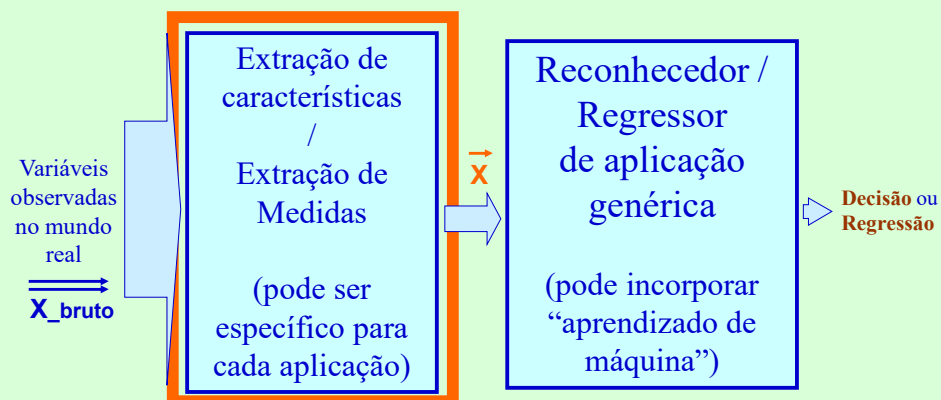


© Prof. Emilio Del Moral Hernandez

53

... O 1o estágio gera um Vetor de Medidas,  $\vec{x}$   
(o segundo estágio operará sobre tal vetor)

54



© Prof. Emilio Del Moral Hernandez

54

## Alguns exemplos de grandezas componentes dos vetores de medidas X:

55

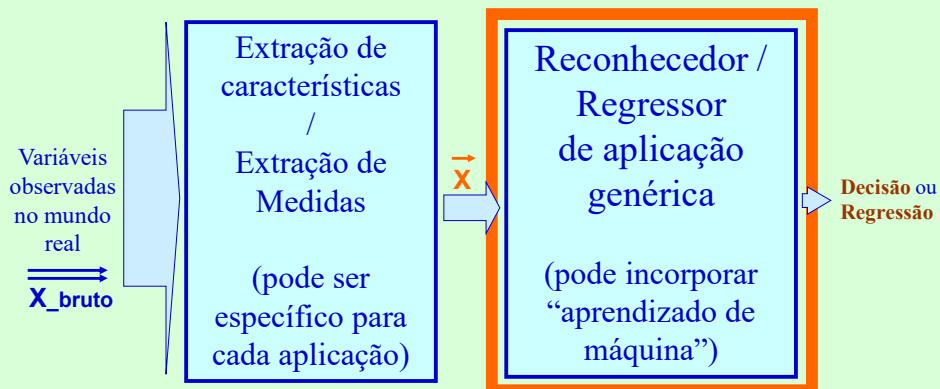
- Grandezas macroscópicas como energia do sinal, amplitude, frequência média ...
- Componentes de diversas harmônicas (análise em frequência)
- Componentes de análise tempo-frequência
- Intensidades luminosas ou intensidades em canais de cor (RGB por ex.)
- Histogramas de intensidades
- Principal Components (componentes principais – PCA)
- Medidas sobre séries temporais (médias móveis, por exemplo; medidas de dispersão / instabilidade localizadas)
- Medidas específicas à aplicação, experimentadas em problemas similares ao seu, relatadas na literatura técnica como sendo de sucesso

© Prof. Emilio Del Moral Hernandez

55

## O segundo estágio opera sobre o Vetor de Medidas, $\vec{X}$ (o 1o estágio gerou tal vetor)

56

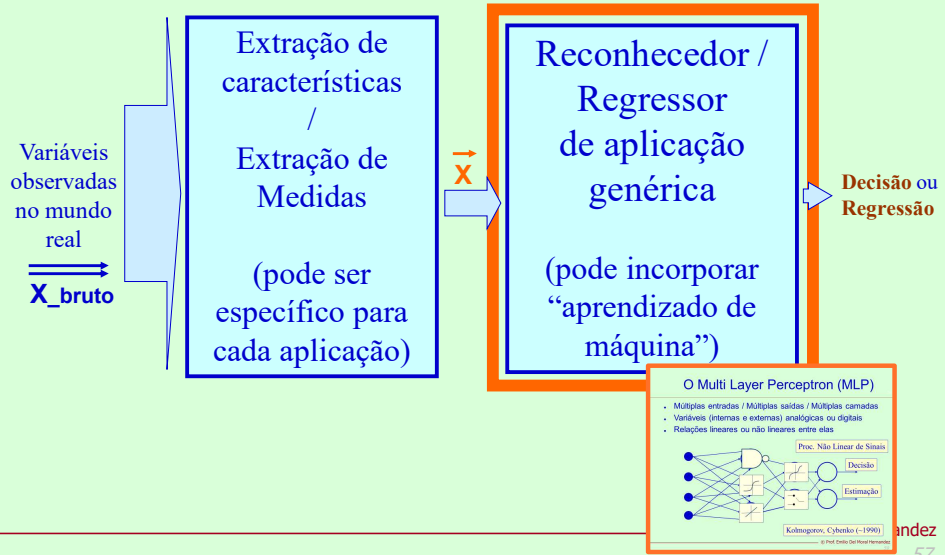


© Prof. Emilio Del Moral Hernandez

56

O segundo estágio opera sobre o Vetor de Medidas,  $\vec{x}$  (o 1o estágio gerou tal vetor)

57



*Exemplos concretos de técnicas de extração de características / extração de medidas em projetos reais*

## PSI3571 – Práticas em Reconhecimento de Padrões, Modelagem e Inteligência Computacional (Eletiva PSI de 5º ano)

<https://edisciplinas.usp.br/course/view.php?id=75248#section-1>

66

Materiais e Informações Perenes - relevantes e úteis ao longo de todo o semestre

- Ementa do Jupiter USP - PSI3571
- RESUMO DAS APRESENTAÇÕES FINAIS DOS PROJETOS DE PSI3571 EM 2018
- RESUMO DAS APRESENTAÇÕES FINAIS DOS PROJETOS DE PSI2672 EM 2017
- Lista / Inventario com Projetos PSI 2672 de 2011 ate 2016
- Repositório (36Mb) de apresentações finais de PSI2672 nos anos 2011 a 2016 ~ perto de 50 ; projetos de alunos de 5o ano / Prof Emilio Del Moral Hernandez
- Pós Graduação --- Vitrine com 10 apresentações finais de PSI5886-2018 (Princípios de Neurocomputação - Pós Grad); apresentações finais dos 10 grupos de alunos que cursaram a disciplina em 2018

<https://edisciplinas.usp.br/mod/url/view.php?id=2794728>

© Prof. Emilio Del Moral Hernandez

## Exemplos de projetos concebidos e realizados por alunos da disciplina PSI-2672

67

PSI 2672 - Práticas em Reconhecimento de Padrões, Modelagem e Neurocomputação [Jupiter](#)

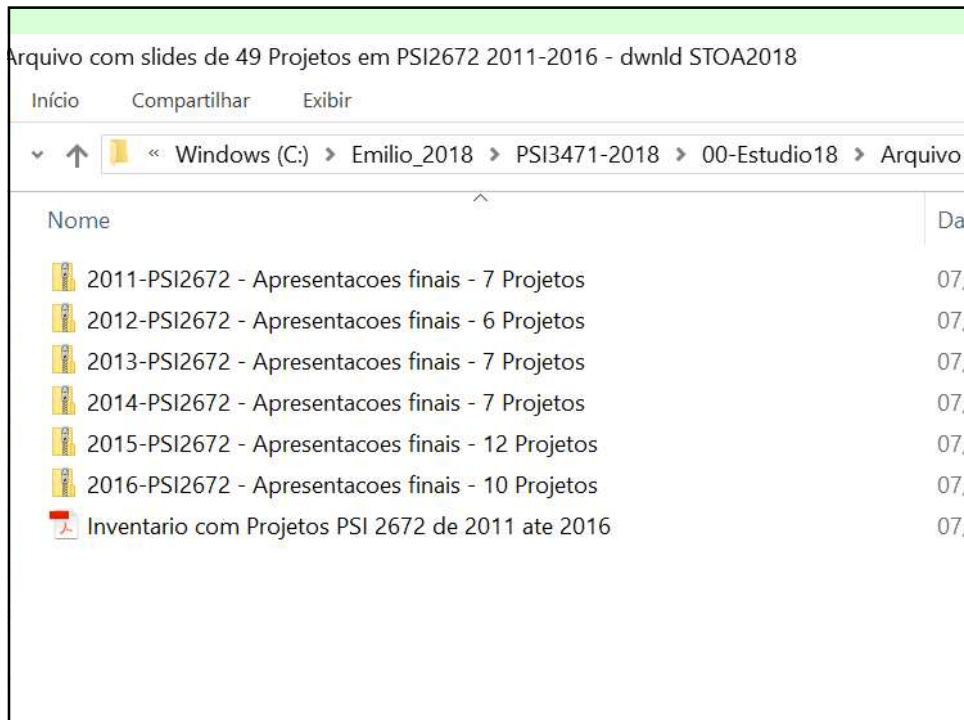
material  
bibliografia  
exemplos  
2011

**Projetos finais:**

1. Classificação em gêneros musicais ([gr\\_I\\_apresentacao\\_Musicas.pdf](#))
2. Implementação de um sistema para correção da medida de um sensor de pressão diferencial ([gr\\_II\\_Apresentacao\\_ma\\_sensor\\_pressao\\_03\\_01.pdf](#))
3. Análise da qualidade dos vinhos a partir de testes físicos-químicos ([gr\\_III\\_apresentacao\\_PSI2672 - Análise de vinhos.pdf](#))
4. Reconhecimento de placas de trânsito ([gr\\_IV\\_apresentacao\\_Reconhecimento\\_de\\_placas.pdf](#))
5. Reconhecedor de alcoolismo ([gr\\_V\\_apresentacao\\_Reconhecedor Alcoolismo.pdf](#))
6. Língua eletrônica ([gr\\_VI\\_apresentacao\\_lingua\\_eletronica.pdf](#))
7. Reconhecimento de dígitos ([gr\\_VII\\_apresentacao\\_Reconhecedor de digitos.pdf](#))

Informações sobre o programa do curso: [Programa PSI2672\\_2011.pdf](#)

© Prof. Emilio Del Moral Hernandez



## Seguidor do alvo dos olhos na tela do computador

**Eye-tracker – Definição do problema**

"Utilizar técnicas neurais para determinar a posição (x,y) para a qual os olhos do usuário estão apontados na tela"

**Coleta de dados**

Objetivos e limitações → Coleta de dados → Pré-processamento → Treino, teste e otimização

**Método semi-automático de coleta de dados:**

- Divisão da tela do computador em 25 quadrantes
- Para cada quadrante, tirar 20 fotos do olho (somente do olho, não do rosto todo!) apontando para a posição (com ajuda de software para tirar fotos e salvá-las)

Total de elementos da amostra: 500 fotos

**Pré-processamento**

Objetivos e limitações → Coleta de dados → Pré-processamento → Treino, teste e otimização

*projeto de alunos em PSI-2672*



## Classificação automática de generos musicais


71

### DESCRIÇÃO DO PROBLEMA

Categorizar músicas em gêneros automaticamente baseado em trechos de suas gravações e exemplos rotulados *a priori*

- 1) Blues
- 2) Classical
- 3) Country
- 4) Disco
- 5) Hip-Hop
- 6) Jazz
- 7) Metal
- 8) Pop
- 9) Reggae
- 10) Rock

### A SOLUÇÃO



*projeto de alunos em PSI-2672*

© Prof. Emilio Del Moral Hernandez

71

Inventário de Projetos Desenvolvidos em PSI 2672 - Práticas em Reconhecimento de Padrões, Modelagem e Neurocomputação, nas 6 turmas de 2011 a 2016  
prof. Emilio Del Moral Hernandez

72

#### Ano 2016

- Cancelador ativo de ruído
- Classificação de fibrilação atrial a partir de eletrocardiograma
- Classificador de movimentos a partir de acelerômetro vestível
- Estimador de Valor de Ações (Flutuações Financeiras e Predição)
- Estimador de desempenho em redação (desempenho escolar)
- Medidor da qualidade da água
- Reconhecedor de dígitos de placas de veículos
- Reconhecedor de imagens de frutas
- Rec. da intenção de mover a mão direita e a esquerda a partir de sinais cerebrais

#### Ano 2015

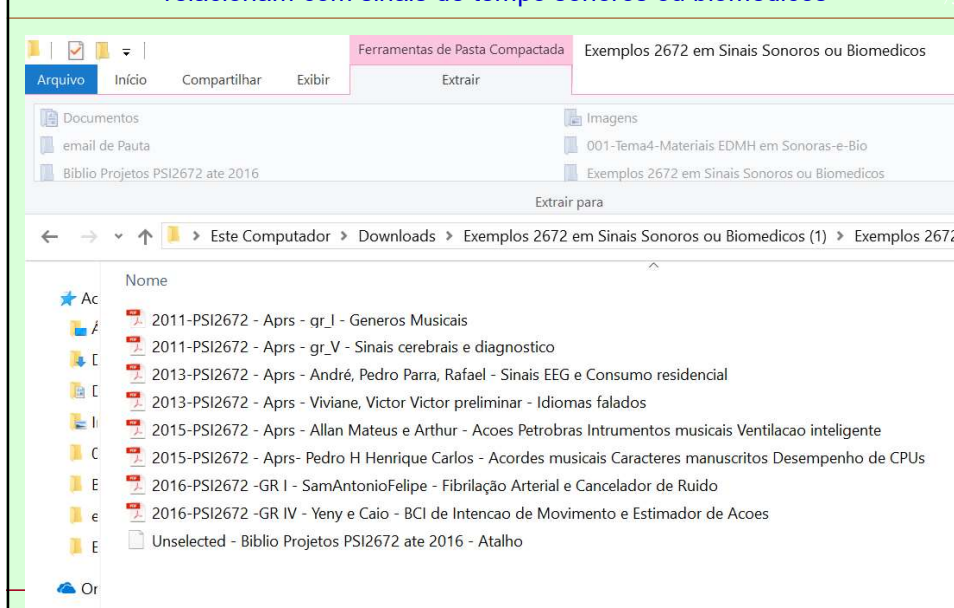
- Estimador do valor de fechamento das acoes da Petrobras
- Classificador de instrumentos musicais
- Regressor embarcado para ventilacao inteligente
- Solar Power Production Estimation (Software for a Smart Metering device)
- Reconhecedor de Objetos em Imagens Digitais
- Reconhecimento de Folhas a Partir de Fotos com Fundo Branco
- Benchmark de CPUs: um regressor multivariado de desempenho
- Reconhecedor de caracteres: um classificador de padroes
- Reconhecedor de acordes musicais: um classificador de padroes
- Deteção de Fraudes em Compras no Cartão
- Padrões nos Sobreviventes e Vítimas do Titanic
- Estimador de pigmentos para tintas a partir de uma amostra

© Prof. Emilio Del Moral Hernandez

72

<b>Ano 2014</b>	<ul style="list-style-type: none"> <li>Identificador de sistema dinâmico</li> <li>Previsor Futebolístico</li> <li>Eye tracker</li> <li>Reconhecimento de placas de automóveis</li> <li>Reconhecimento de padrões de consumo em aparelhos aplicado a Smart Grids</li> <li>Estimativa de preços de carros</li> <li>Classificador de cogumelos venenosos</li> </ul>
<b>Ano 2013</b>	<ul style="list-style-type: none"> <li>Classificação de sinais de EEG e relação com epilepsia</li> <li>Estimador de consumo de eletricidade residencial</li> <li>Análise Sentimental de notícias</li> <li>Identificação de um Pixel Isolado em uma Imagem Simples</li> <li>Preditor de sobrevivência em pacientes Cardíacos</li> <li>Estimador do grau do mal de Parkinson</li> <li>Classificador de idiomas</li> </ul>
<b>Ano 2012</b>	<ul style="list-style-type: none"> <li>Classificação da Qualidade do Leite</li> <li>Estimador de PH para amostras de vinho</li> <li>Previsão de Ações na Bolsa de Valores (reconhecedor de padrões)</li> <li>Previsão de Ações na Bolsa de Valores (estimador)</li> <li>Reconhecedor de Combustível Adulterado</li> </ul>
<b>Ano 2011</b>	<ul style="list-style-type: none"> <li>Classificação em Gêneros Musicais</li> <li>Estimador de Correção do Erro de um Sensor de Pressão Diferencial</li> <li>Análise da qualidade de vinhos baseado em características físico-químicas</li> <li>Sistema de reconhecimento de Placas de Trânsito</li> <li>Reconhecedor de Alcoolismo e Sinais Cerebrais</li> <li>Língua eletrônica para a determinação de propriedades do leite</li> </ul>

**Pinçando alguns projetos (desenvolvidos no PSI em disciplinas de 5º ano) envolvendo reconhecimento de padrões / regressão multivariada que se relacionam com sinais de tempo sonoros ou biomédicos**



# PSI2672 – Classificação de gêneros musicais

## Projeto de Chamon e Gabriel


76

### DESCRIÇÃO DO PROBLEMA

Categorizar músicas em gêneros automaticamente baseado em trechos de suas gravações e exemplos rotulados *a priori*

- 1) Blues
- 2) Classical
- 3) Country
- 4) Disco
- 5) Hip-Hop
- 6) Jazz
- 7) Metal
- 8) Pop
- 9) Reggae
- 10) Rock

### A SOLUÇÃO



projeto de alunos em PSI-2672

© Prof. Emilio Del Moral Hernandez

76

# PSI2672 – Classificação de gêneros musicais

77

2011-PSI2672 - Aprs - gr\_I - Generos Musicais.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas 2011-PSI2672 - Apr... x Fazer login

5 / 32 72,1%

Introdução Features RNA Resultados

### FEATURES

**20 MFCCs [2]**  
Muito usado em reconhecimento de voz. É uma medida de variações no tom.  
$$MFCC = | \mathcal{F} \{ \log[ mel(|S(f)|^2) ] \} |^2$$

**RMS [2]**  
Usado como medida da energia média da música.  
$$RMS = \sqrt{\frac{1}{T} \int_{-T/2}^{T/2} s^2(t) dt}$$

**Spectral Centroid [2]**  
Uma espécie de centro de massa do espectro, determina uma relação entre altas e baixas frequências.  
$$C = \frac{\sum_{f=0}^M f \cdot |S(f)|^2}{\sum_{f=0}^M |S(f)|^2}$$

© Prof. Emilio Del Moral Hernandez

77

## PSI2672 – Classificação de gêneros musicais

78

2011-PSI2672 - Aprs - gr\_J - Generos Musicais.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas 2011-PSI2672 - Apr... x Fazer logon

6 / 32 72,1%

Introdução Features RNA Resultados

### FEATURES

Spectral bandwidth [2]  
Mede a variação do espectro em torno da centróide espectral.

$$B^2 = \frac{\sum_{f=0}^M (f - c)^2 |S(f)|^2}{\sum_{f=0}^M |S(f)|^2}$$

Zero-crossing [2]  
Representa uma medida do "ruído" de fundo em uma música. Trata-se simplesmente do número de cruzamentos por zero no domínio do tempo.

Band energy ratio [2]  
Razão da energia no primeiro quarto do espectro com relação ao espectro todo.

$$BER = \frac{\sum_{f=0}^{M/4} |S(f)|^2}{\sum_{f=0}^M |S(f)|^2}$$

© Prof. Emilio Del Moral Hernandez

78

## PSI2672 – Classificação de gêneros musicais

79

2011-PSI2672 - Aprs - gr\_J - Generos Musicais.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas 2011-PSI2672 - Apr... x Fazer logon

7 / 32 72,1%

Introdução Features RNA Resultados

### FEATURES

Octave spectral contrast [3]  
Medida da diferença entre espectros em bandas de oitava.

$$Valley_k = \log \left( \frac{1}{\alpha N} \sum_{f=0}^{\alpha N} |S(f)| \right), \quad Peak_k = \log \left( \frac{1}{\alpha N} \sum_{f=0}^{\alpha N} |S(N - f + 1)| \right)$$
$$SC_k = Peak_k - Valley_k$$

Loudness [4]  
Modelo psicoacústico de sensação sonora ("intensidade" percebida).

Sharpness [4]  
Medida de conteúdo espectral de altas frequências. Avaliação psicoacústica do quão "afiado", "agudo" um som é.

© Prof. Emilio Del Moral Hernandez

79

## PSI2672 - Gabriel, Maria Luisa e Ricardo - EEG

80

2011-PSI2672 - Aprs - gr\_V - Sinais cerebrais e diagnostico.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas 2011-PSI2672 - Apr... x Fazer logon

7 / 26 72,1%

### O EEG

**Eletroencefalograma**

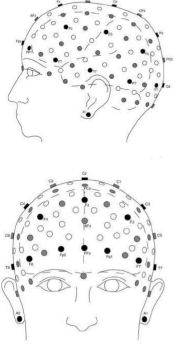
Potenciais elétricos ( $\mu\text{V}$ )

**64 sensores**

↓

Taxa de amostragem 256Hz/canal

**16384 amostras/s**



Fonte: [http://bindcenter.eu/?page\\_id=12](http://bindcenter.eu/?page_id=12) Reconhecedor de Alcoolismo | 7

© Prof. Emilio Del Moral Hernandez

## PSI2672 - Gabriel, Maria Luisa e Ricardo - EEG

81

2011-PSI2672 - Aprs - gr\_V - Sinais cerebrais e diagnostico.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas 2011-PSI2672 - Apr... x Fazer logon

10 / 26 72,1%

### Pré-processamento

Eliminação de ruídos oculares e musculares

↓

Obtenção da FFT dos sinais temporais

↓

Obtenção dos centróides

↓

Normalização da matriz centróides

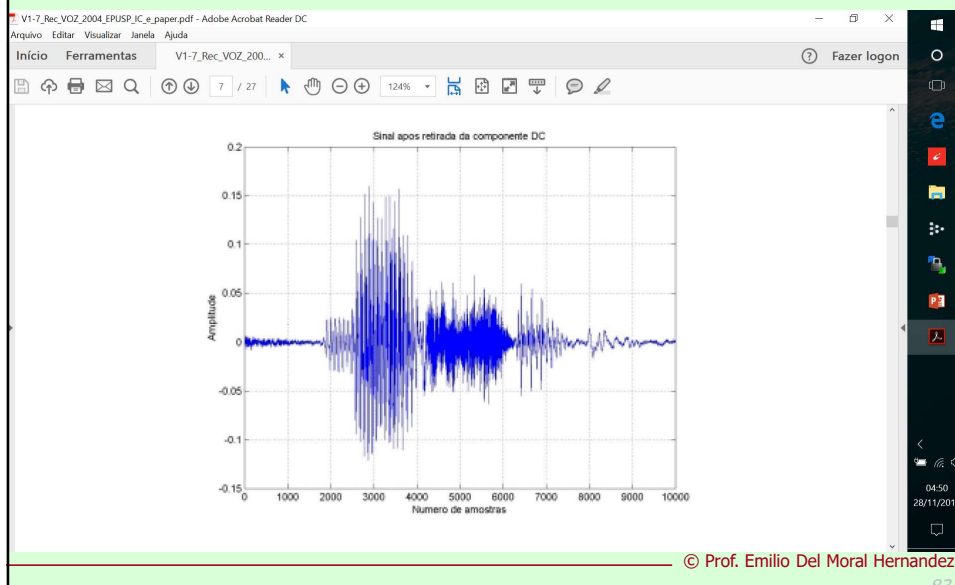
Reconhecedor de Alcoolismo | 10

© Prof. Emilio Del Moral Hernandez

*Entendendo os fundamentos da análise tempo frequência (uma classe de extratores importante)*

## TCC em Reconhecimento de comandos de voz (Daniel e Gabriel) – sobe, desce, esquerda, direita

83



© Prof. Emilio Del Moral Hernandez

## Medida de qualidade do reconhecedor de 4 comandos de voz ensaiado ...

84

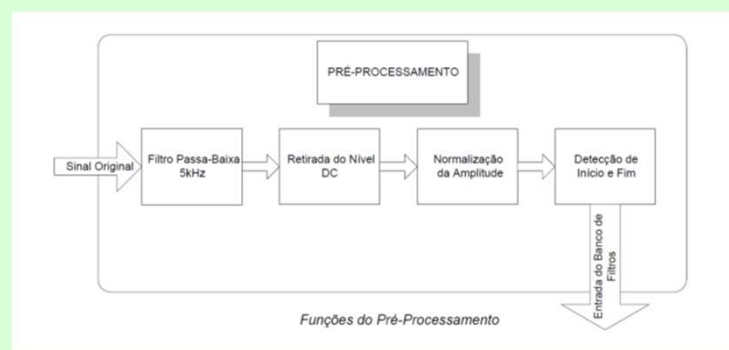
amostra \ resultado	SOBE	DESCE	ESQUERDA	DIREITA
SOBE	85%	0%	15%	0%
DESCE	0%	100%	0%	0%
ESQUERDA	0%	0%	80%	20%
DIREITA	0%	0%	10%	90%

© Prof. Emilio Del Moral Hernandez

84

## Exemplo de pré-processamentos num reconhecedor de comandos de voz - TCC de Daniel e Gabriel

85



© Prof. Emilio Del Moral Hernandez

85

## TCC em Reconhecimento de comandos de voz (Daniel e Gabriel) – sobe, desce, esquerda, direita

86

V1-7\_Rec\_VOZ\_2004\_EPUSP\_IC\_e\_paper.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas V1-7\_Rec\_VOZ\_200... x Fazer logon

11 / 27 75%

Tabela 1

Frequências centrais e bandas de passagem do banco de filtros	
	0
Filtro 1	$f_{c1} = 50$ Hz
	100
Filtro 2	$f_{c2} = 150$ Hz
	200
Filtro 3	$f_{c3} = 250$ Hz
	300
Filtro 4	$f_{c4} = 350$ Hz
	400
Filtro 5	$f_{c5} = 450$ Hz
	510
Filtro 6	$f_{c6} = 570$ Hz
	630
Filtro 7	$f_{c7} = 700$ Hz
	770
Filtro 8	$f_{c8} = 840$ Hz
	920
Filtro 9	$f_{c9} = 1000$ Hz
	1080
Filtro 10	$f_{c10} = 1170$ Hz
	1270
Filtro 11	$f_{c11} = 1270$ Hz
	1380
Filtro 12	$f_{c12} = 1490$ Hz
	1620
Filtro 13	$f_{c13} = 1850$ Hz
	2000
Filtro 14	$f_{c14} = 2150$ Hz
	2320
Filtro 15	$f_{c15} = 2500$ Hz
	2700
Filtro 16	$f_{c16} = 2900$ Hz
	3150
Filtro 17	$f_{c17} = 3400$ Hz
	3700
Filtro 18	$f_{c18} = 4000$ Hz
	4400
Filtro 19	$f_{c19} = 4800$ Hz
	5300

© Prof. Emilio Del Moral Hernandez

86

## TCC em Reconhecimento de comandos de voz (Daniel e Gabriel) – sobe, desce, esquerda, direita

87

at Reader DC

00... x

75%

Tabela 1

Frequências centrais e bandas de passagem do banco de filtros	
	0
Filtro 1	$f_{c1} = 50$ Hz
	100
Filtro 2	$f_{c2} = 150$ Hz
	200
Filtro 3	$f_{c3} = 250$ Hz
	300
Filtro 4	$f_{c4} = 350$ Hz
	400
Filtro 5	$f_{c5} = 450$ Hz
	510
Filtro 6	$f_{c6} = 570$ Hz



*Sistema auditivo,  
Sistema fonador,  
Mel Freq Cepstrum*

The screenshot shows a web browser window with the search query "coclea - Pesquisa". The search results display several anatomical diagrams of the human ear and cochlea. The diagrams include:

- A cross-section of the ear showing the external ear, ear canal, eardrum, ossicles, and cochlea.
- A detailed view of the cochlea with labels for the Vestibular membrane, Cochlear duct with endolymph, Organ of Corti, Basilar membrane, Scala vestibuli with perilymph, Scala cochlearis with perilymph, and Scala tympani with perilymph.
- A diagram of the cochlea with labels for the Rampa vestibular, Membrana tectoria, Rampa timpânica, Rampa timpânica inferior, Membrana basilar, and Canal coclear.
- A diagram of the cochlea with labels for the Vestibulo, Utriculo, Cochlea, and Sievo.
- A diagram of the cochlea with labels for the Conducto semicircular posterior, Conducto semicircular anterior, and Conducto semicircular horizontal.
- A diagram of the cochlea with labels for the Rampa vestibular, Membrana Basilar, Rampa timpânica, and Membrana tectoria.
- A diagram of the cochlea with labels for the Dura Cochlear, Membrana tectoria, Membrana basilar, and Membrana tectoria.
- A diagram of the cochlea with labels for the Membrana tectoria, Membrana basilar, and Membrana tectoria.
- A diagram of the cochlea with labels for the Membrana tectoria, Membrana basilar, and Membrana tectoria.

The browser's address bar shows the URL: <https://www.google.com.br/search?q=coclea&source=Inms&tbn=isch&sa=X&ved=0ahUKEwi:>

The browser's taskbar shows the time 15:54, quarta-feira, 22/08/2018.

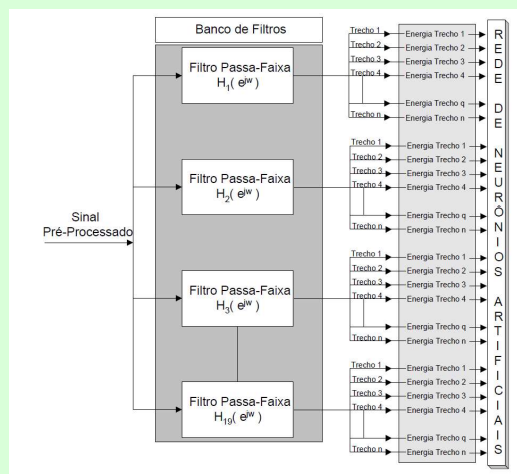
© Prof. Emilio Del Moral Hernandez

91

91

## TCC em Reconhecimento de comandos de voz (Daniel e Gabriel) – sobe, desce, esquerda, direita

93




© Prof. Emilio Del Moral Hernandez

93

*Espectrograma –  
Conceito importante no cenário  
de análise tempo-frequência*

The screenshot shows the Wikipedia article for 'Spectrogram'. The page title is 'Spectrogram' and it includes a search bar, navigation tabs (Article, Talk), and a list of contents. The main text explains that a spectrogram is a visual representation of the spectrum of frequencies of sound or other signal as they vary with time. It also includes a small image of a spectrogram and a caption: 'Typical spectrogram of the spoken words "nineteenth century". Frequencies are shown increasing up the vertical axis, and time on the horizontal axis. The lower frequencies are more dense because it is a male voice. The legend to the right shows that the color intensity increases with the density.'



*Entendendo os fundamentos da Análise de Componentes (estatisticamente) Principais*

*PCA – Principal Component Analysis*

*(uma técnica de extração importante)*



# PCA – Principal Components Analysis

## Teoria e Aplicações

Doutor em Ciências (POLI – USP)

[ekitani@lsi.usp.br](mailto:ekitani@lsi.usp.br)

CV Lattes:

<http://lattes.cnpq.br/6731656353508097>



Prof. Dr. Edson C. Kitani

Prof. Dr. Emilio Del Moral Hernandez



## GRUPO DE INTELIGÊNCIA COMPUTACIONAL, MODELAGEM E NEUROCOMPUTAÇÃO ELETRÔNICA – ICONE-EPUSP

LABORATÓRIO DE SISTEMAS INTEGRADOS –LSI  
DEPARTAMENTO DE ENGENHARIA DE SISTEMAS ELETRÔNICOS – PSI  
ESCOLA POLITÉCNICA DA USP



Prof. Dr. Edson C. Kitani

<http://buscatextual.cnpq.br/buscatextual/visualizacv.do?id=K4269320J9>

Formação:

- Tecnico em Eletrônica (ETEP – Santo André)
- Tecnólogo em Automação Industrial (Centro Universitário de Santo André)
- Especialista em Mecânica Fina (Universidade São Judas)
- Mestre em Eng. Elétrica (Centro Universitário da FEI)
- Doutor em Ciências (POLI – USP)


Atividade profissional:

- Professor Associado na FATEC- Santo André (Eletrônica Automotiva)
- Chefe do Departamento de Projetos de Máquinas na Mahle Anéis


[ekitani@lsi.usp.br](mailto:ekitani@lsi.usp.br) [www.lsi.usp.br/~edson](http://www.lsi.usp.br/~edson)

## HISTÓRICO DO PCA

Descrito inicialmente por Karl Pearson no artigo, *“On lines and planes of closest fit to systems of points in space”*, *Philosophical Magazine*, 1901.




1857 - 1936



*“In many physical, statistical, and biological investigations it is desirable to represent a system of points in plane, three or higher dimensioned space by the best-fitting straight line or plane” (Pearson, 1901).*

## Para 3 Dimensões



$$\bar{\mathbf{x}} = \frac{1}{N} \sum_{i=1}^N \mathbf{x}_i$$

$$\Sigma_{\mathbf{x}} = \frac{1}{(N-1)} \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^T$$

$$\bar{\mathbf{x}} = [0 \quad 5 \quad 2]^T$$

$$\Sigma_{\mathbf{x}} = \begin{bmatrix} 25 & -1 & 7 \\ -1 & 4 & -4 \\ 7 & -4 & 10 \end{bmatrix}$$

Extraído de Osuna 2002

Prof. Edson Kitani

104

## Exemplo Numérico com Matlab

```
x = [1, 2; 3, 3; 3, 5; 5, 4; 5, 6; 6, 5; 8, 7; 9, 8]
```

```
figure(1)
```


```
scatter(x(:,1),x(:,2))
```

Media = mean(x)

$$\bar{\mathbf{x}} = [5 \quad 5]^T$$

Sigma = cov(x,1)<sup>Nota</sup>

$$\Sigma_{\mathbf{x}} = \begin{bmatrix} 6,25 & 4,25 \\ 4,25 & 3,5 \end{bmatrix}$$



A normalização é realizado para N.

Prof. Edson Kitani

105

## Autovalores ( $\lambda$ ) e Autovetores ( $v$ )

Associado a cada matriz quadrada  $A = ((a_{ij}))$  de ordem  $n$ , temos uma função

$$f(\lambda) = |A - \lambda I| = \begin{vmatrix} a_{11} - \lambda & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} - \lambda & \dots & a_{2n} \\ \dots & \dots & \dots & \dots \\ a_{n1} & a_{n2} & \dots & a_{nn} - \lambda \end{vmatrix}$$

chamada de Função Característica da matriz  $A$ . E a função


$$f(\lambda) = |A - \lambda I| = 0,$$

que pode ser expressa na forma polinomial

$$c_0 \lambda^n + c_1 \lambda^{n-1} + \dots + c_{n-1} \lambda + c_n = 0$$

é chamada de Equação Característica da matriz  $A$ .

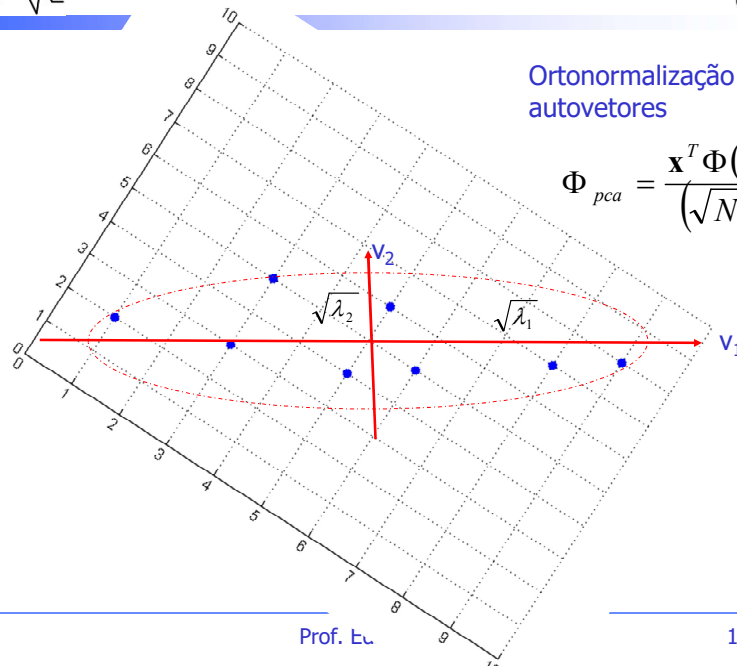
## Exemplo Numérico





Ortonormalização dos autovetores

$$\Phi_{pca} = \frac{\mathbf{x}^T \Phi(\Lambda)^{-\frac{1}{2}}}{(\sqrt{N-1})}$$



Prof. Eu.

108

*Note que pela rotação / mudança de coordenadas, não perdemos qualquer informação na reescrita dos  $X$  e podemos voltar ao sistema original sem qualquer ambiguidade – há uma relação biunívoca entre os  $X$  e os  $X_{reescritos}$*

*Tampouco temos redução de dimensionalidade com a reescrita ....*

110

© Prof. Emilio Del Moral – EPUSP

*E o que acontece se eliminarmos algumas dimensões, e em particular aquelas que apresentam pequeno exercício de dispersão estatística com relação às demais componentes?*

....

*Digamos que eliminemos as últimas componentes, as “menos principais”, mantendo por exemplo as apenas as “mais principais”, as que são responsáveis por digamos 95% ou mesmo 99% da dispersão estatística total?*

111

© Prof. Emilio Del Moral – EPUSP



## TORNARAM O PCA FAMOSO COM EIGENFACES



Alex 'Sandy' Pentland dirige o MIT's Human Dynamics Laboratory e o MIT Media Lab



Matthew Turk é professor na UCLA University of California – Computer Science Department


Matthew Turk & Alex Pentland  
*Eigenfaces for recognition* *Journal of Cognitive Neuroscience* 1991

Prof. Edson Kitani


113

## IMAGEM DAS COMPONENTES PRINCIPAIS

Conjunto de treinamento: 100



As 4 primeiras componentes principais, ou eigenfaces.



Média

1ª PC

2ª PC

3ª PC

4ª PC

Prof. Edson Kitani

114

## RECONSTRUÇÃO DE UMA IMAGEM



Original

1 PCs

10 PCs

50 PCs

99 PCs

Prof. Edson Kitani


115

## IMAGEM DAS COMPONENTES PRINCIPAIS

Conjunto de treinamento: 100



As 4 primeiras componentes principais, ou eigenfaces.



Média

1ª PC

2ª PC

3ª PC

4ª PC

Prof. Edson Kitani

116

## CONCLUSÃO

- O PCA retém as informações mais expressivas.
- Uma imagem de face pode ser representada economicamente em uma base vetorial menor do que a base original.
- As transformações são lineares.
- O PCA não altera o formato da distribuição dos dados.
- É o mais robusto e eficiente Redutor de Dimensionalidade

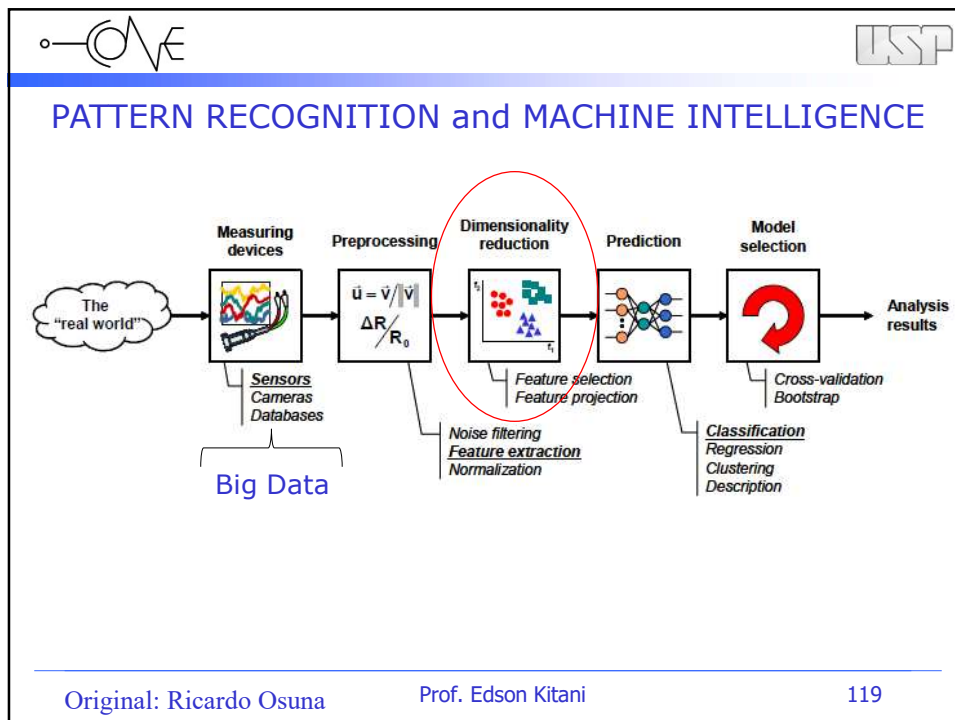
Prof. Edson Kitani

117

*E o PCA é específico para o reconhecimento de faces, como na pesquisa de Edson Kitani?*

118

© Prof. Emilio Del Moral – EPUSP



Original: Ricardo Osuna

Prof. Edson Kitani

119

## Fusão de sensores em línguas eletrônicas

120



E-Tongue na análise de uma amostra de café

© Prof. Emilio Del Moral Hernandez

120

## Fusão de sensores em línguas eletrônicas

121



Foto de um conjunto de eletrodos de ouro, que compõe uma língua eletrônica, recoberto com filmes ultrafinos (Imagem: Osvaldo Novais)

© Prof. Emilio Del Moral Hernandez

121

## Língua Eletrônica para controle de qualidade alimentar e detecção de substâncias nocivas

122



1. Gordura
2. Proteína
3. Lactose
4. pH

- Sistema com 4 sensores;
- Sistema com 5 frequências diferentes em cada sensor;
  - $4 \times 5 = 20$  entradas para a RNA

*projeto de alunos em PSI-2672*

© Prof. Emilio Del Moral Hernandez

122





*Auto Encoders*  
(em uma forma simples)

*Uma técnica de extração similar à PCA e bastante em uso no universo do Deep Learning*

## Autoencoders e Stacked Auto-encoders

(imagens da internet)

126



Algumas ferramentas em Deep Learning


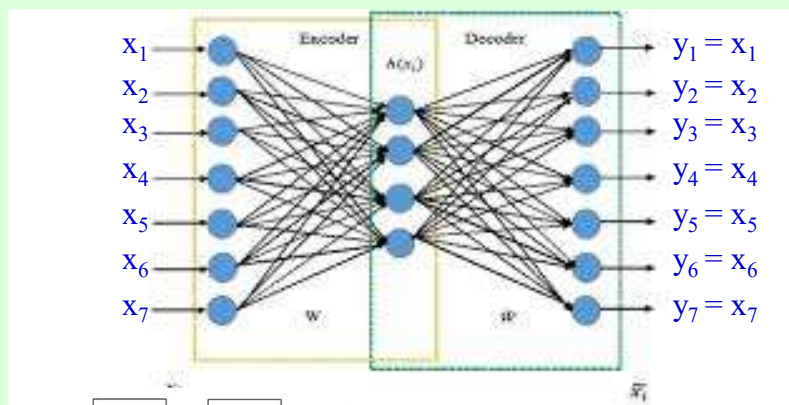
© Prof. Emilio Del Moral Hernandez

126

## Um autoencoder detalhado

(imagem da internet, adaptada)

127



Um pouquinho de Deep Learning

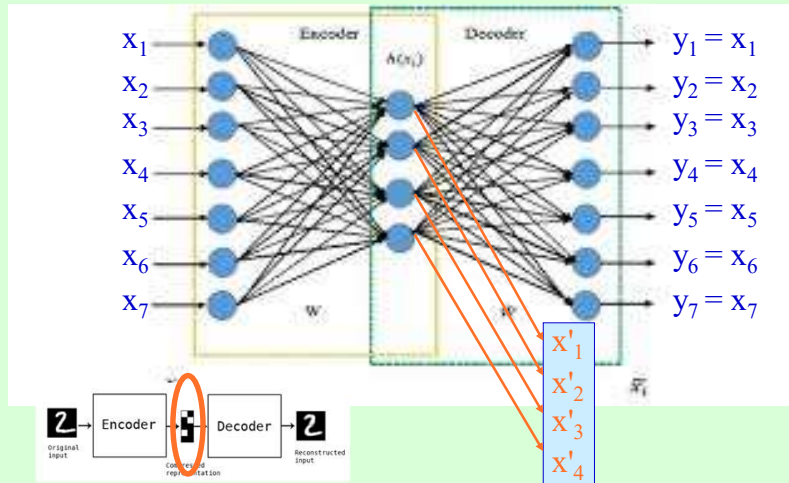
© Prof. Emilio Del Moral Hernandez

127



Um autoencoder detalhado  
(imagem da internet, adaptada)

128



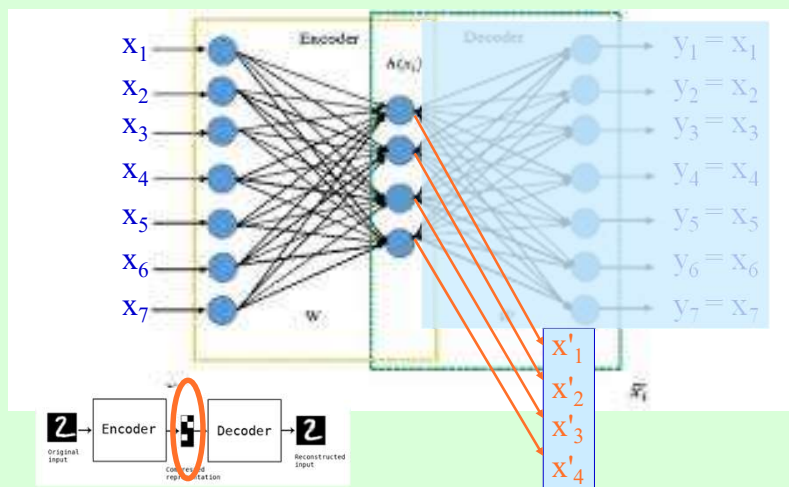
Algumas ferramentas em Deep Learning

© Prof. Emilio Del Moral Hernandez

128

Um autoencoder detalhado  
(imagem da internet, adaptada)

129




Algumas ferramentas em Deep Learning

© Prof. Emilio Del Moral Hernandez

129

## Autoencoders e Stacked Auto-encoders (imagens da internet)

130



Algumas ferramentas em Deep Learning

© Prof. Emilio Del Moral Hernandez

130

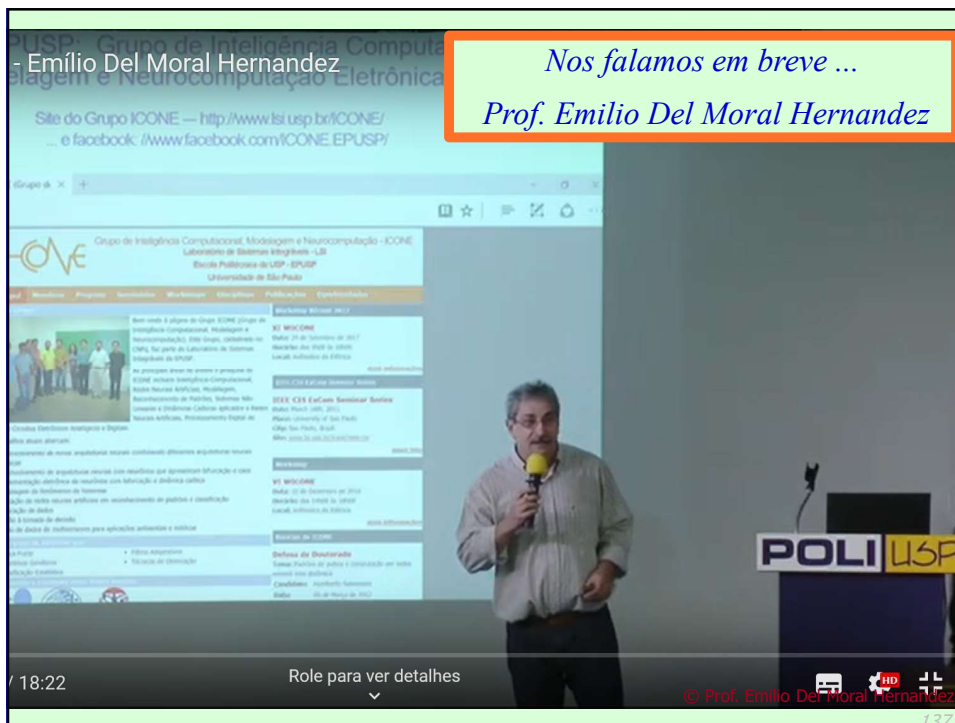
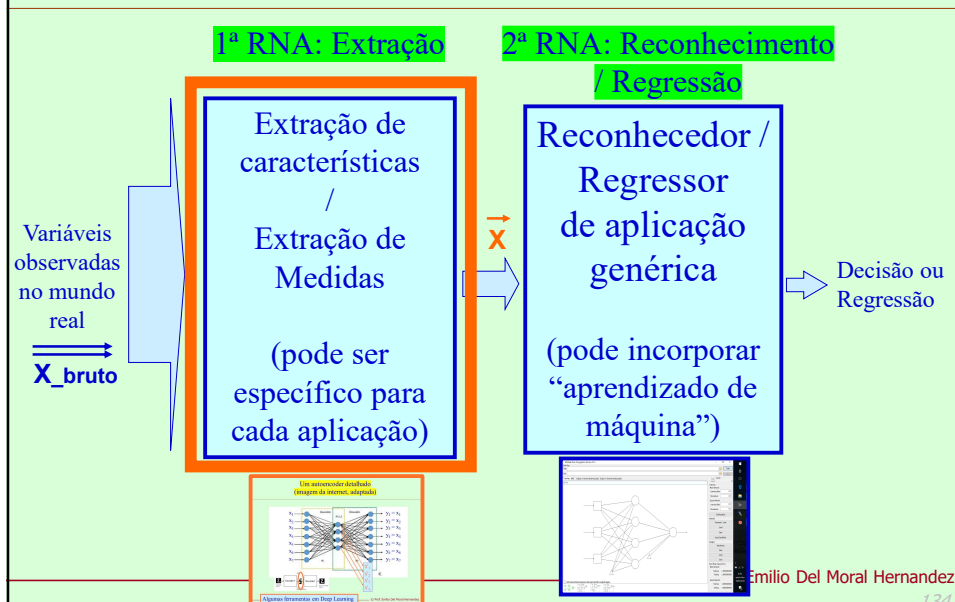
*Note que nesta técnica, o primeiro estágio da “solução em dois estágios” também é uma rede neural (não só o segundo estágio é uma RNA), mas esse primeiro estágio é uma RNA específica, desenhada apenas para a codificação compacta de variáveis; ela não realiza a regressão ou o reconhecimento, que são feitos pela segunda rede neural.*

13

© Prof. Emilio Del Moral – EPUSP

... O 1o estágio gera um Vetor de Medidas,  $\vec{X}$   
 (o segundo estágio operará sobre tal vetor)

134



slides extras  
seguem ....

+ Exemplos concretos de técnicas de extração de características / extração de medidas em projetos reais

## PSI2672 – André, Pedro, Rafael - EEG

141

2013-PSI2672 - Aprs - André, Pedro Parra, Rafael - Sinais EEG e Consumo residencial.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas 2013-PSI2672 - Apr... x 72,1% Fazer logon

9 / 28

Introdução Features RNA Resultados 9/28

### Features

Média do desvio-padrão das amplitudes

$$m_j^x = \frac{1}{N^x} \sum_{i=1}^{N^x} |x_i - \bar{x}| \quad (1)$$

Flutuação do desvio-padrão das amplitudes

$$F^x = \frac{1}{n} \sum_{j=1}^n |m_j^x - \bar{m}^x|, \quad (2)$$

Média do desvio-padrão do centro de frequência

$$m_j^w = \frac{2}{N^w} \sum_{f=1}^{N^w/2} \frac{\omega_f S(\omega_f)}{S(\omega_f)} \quad (3)$$

Flutuação do desvio-padrão das amplitudes

$$F^w = \frac{1}{n} \sum_{j=1}^n |m_j^w - \bar{m}^w|, \quad (4)$$

© Prof. Emilio Del Moral Hernandez

08:33 21/11/2017

## PSI2672 – Victor, Victor, Viviane – Idiomas falados

142

2013-PSI2672 - Aprs - Viviane, Victor Victor preliminar - Idiomas falados.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas 2013-PSI2672 - Apr... x 72,1% Fazer logon

5 / 22

### EXTRAÇÃO DE CARACTERÍSTICAS

- Primeiro conjunto de características:
  - RMS[1]: usado como energia média do sinal

$$RMS = \sqrt{\frac{1}{T} \int_{-T/2}^{T/2} s^2(t) dt}$$

- Spectral Centroid[1]: análogo ao centro de massa para o espectro

$$C = \frac{\sum_{f=0}^M f \cdot |S(f)|^2}{\sum_{f=0}^M |S(f)|^2}$$

© Prof. Emilio Del Moral Hernandez

142

## PSI2672 – Allan, Mateus, Arthur – Instrumentos musicais

143

2015-PSI2672 - Aprs - Allan Mateus e Arthur - Acoes Petrobras Instrumentos musicais Ventilacao inteligente.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas 2013-PSI2672 - Apr... 2015-PSI2672 - Apr... x 72,1% Fazer logon

27 / 56

### O que é o Cepstrum?

- Eu não sei!
- Definição formal:
$$\left| F^{-1} \{ \log_{10} ( | F \{ f(t) \} |^2 ) \} \right|^2$$
- “O módulo ao quadrado da transformada inversa de Fourier calculada sobre logaritmo de base 10 calculada sobre módulo ao quadrado da transformada de Fourier do sinal f(t)!”

27 Escola Politécnica da USP

© Prof. Emilio Del Moral Hernandez

143

# PSI2672 – Carlos, Henrique e Pedro - Acordes

144

2015-PSI2672 - Aprs- Pedro H Henrique Carlos - Acordes musicais Caracteres manuscritos Desempenho de CPUs.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas 2015-PSI2672 - Apr... x Fazer login

## Reconhecimento de Acordes

1ª iteração: Pré-processamento

**Downsampling**

Fonte: J. de Jesus Guerrero-Turrubiates, S. Gonzalez-Reyna, S. Ledesma-Orozco e J. Avina-Cervantes

© Copyright 2015 - cmori, hogawa, phayashi PSI2672 - Apresentação final e demonstração de resultados 49/53

© Prof. Emilio Del Moral Hernandez

21:21 21/11/2017

145

145

*Importância de testar várias possibilidades de extração de características / extração de medidas*

## Exemplo de modelagem / reconhecimento automático de padrões ... (tese de Liselene / Prof Miguel)

The screenshot shows a PDF viewer window with the following content:

- Window title: defesa08Abr2011\_Liselene.pdf - Adobe Acrobat Reader DC
- Menu: Arquivo, Editar, Visualizar, Janela, Ajuda
- Toolbar: Início, Ferramentas, defesa08Abr2011\_L... x, 1 / 35, 63.6%, Compartilhar
- Slide content:
  - Title: Extração de parâmetros característicos para detecção acústica de vazamento de água
  - Author: Aluna: Liselene de Abreu Borges
  - Advisor: Orientador: Miguel Arjona Ramírez
- System tray: 07:54, segunda-feira, 15/10/2018
- Footer: © Prof. Emilio Del Moral Hernandez



## Exemplo de modelagem / reconhecimento automático de padrões ... (tese de Liselene / Prof Miguel)

149

Curso: PSI3472 - Concepção | Disciplina: PSI2672 do Grup | Sistemas de detecção e clas | Extração de parâmetros

teses.usp.br/teses/disponiveis/3/3142/tde-19072011-110149/pt-br.php

**Biblioteca Digital USP**

*Teses e Dissertações*

Início

Tese de Doutorado

DOI: 10.11066/T.2011.tde-19072011-110149

Documento: Tese de Doutorado

Autor: Borges, Liselene de Abreu (Catálogo USP)

Nome completo: Liselene de Abreu Borges

E-mail:

Unidade da USP: Escola Politécnica

Área de Conhecimento: Sistemas Eletrônicos

Data de Defesa: 2011-04-08

Imprenta: São Paulo, 2011

Orientador: Aljona Ramirez, Miguel (Catálogo USP)

Banca examinadora: Alcaim, Abraham; Del Moral Hernandez, Emilio; Figueiredo, Rubem Dutra Ribeiro; Queiroz, Manoel Gomes de

**Título em português:** Extração de parâmetros característicos para detecção acústica de vazamento de água.

**Palavras-chave em português:** Máquina de vetores de suporte; Predição linear; Processamento de sinais; Vazamento de água.

**Resumo em português:** Este trabalho apresenta a pesquisa sobre a extração de parâmetros característicos de sinais acústicos para fins de detecção automática de vazamento de água em tubulações enterradas. Os sinais acústicos foram adquiridos com o auxílio de um geofone eletrônico e também catalogados por técnicos especialistas em detecção acústica. De todos os sinais foram extraídos os modelos de predição linear percussivos de vários ordens, determinando-se como melhor a ordem 2. A partir de um conjunto de modelos de referência de sinais de vazamento, a distância média de Itallura dos outros modelos em relação a estas referências foram calculadas. Em conjunto com estas distâncias, quatro características espectrais são também utilizadas do sinal e fim de conjunto o vetor de parâmetros característicos do sinal. Parte destes vetores de parâmetros característicos são utilizados para treinar o classificador de máquina de vetores de suporte. O restante dos sinais são então submetidos a este classificador que obtém a taxa de acerto de classificação em torno de 90%. Experimentos anteriores, utilizando modelos de predição linear, de ordem 10, obtiveram uma taxa de acerto em torno de 62%, isso demonstra que estes novos parâmetros característicos propostos atingem os objetivos deste trabalho, que são algoritmos com melhor taxa de acerto na detecção de vazamentos.

**Título em inglês:** Feature extraction for acoustic water leak detection.

**Palavras-chave em inglês:** Linear prediction; Signal processing; Support vector machine; Water leak.

**Resumo em inglês:** This work presents a research about feature extraction of acoustic signals for detection of water leak in buried pipes. Acoustic signals were acquired by means of an electronic geophone and also labeled by technicians specialized in acoustic water leak detection. For every signal, its linear predictive model was estimated for a range of prediction orders, concluding for the best order 2. Out of this group of models, some key ones are used as reference for calculating the Itallura

**Serviços**

Trabalhos decorrentes

Estadísticas

Visualizar: 426

Downloads: 296

Como citar

Formato MARC

Formato OAI DC

© Prof. Emilio Del Moral Hernandez

## Exemplo de modelagem / reconhecimento automático de padrões ... (tese de Liselene / Prof Miguel)

150

### O procedimento de detecção do Vazamento

- \* Haste de escuta
- \* Correlacionador de ruído
- \* Geofone





© Prof. Emilio Del Moral Hernandez

150

151

defesa08Abr2011\_Liselene.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

defesa08Abr2011\_L... x

Fazer login

Compartilhar

## Os Tipos de Vazamentos

\* Tipos de vazamentos: (a) Inerentes, (b) Não Visíveis e (c) Visíveis;

© Prof. Emilio Del Moral Hernandez

151

## Exemplo de modelagem / reconhecimento automático de padrões ... (tese de Liselene / Prof Miguel)

152

## Sistema de Detecção de Vazamento

```

    graph LR
      sinal --> Aquisicao[Aquisição do sinal]
      Aquisicao --> Pre[Pré-processamento]
      Pre --> Extra[Extração de características]
      Extra --> Class[Classificação]
      Class --> decisao[decisão]
      Class --> Treinamento[Treinamento do classificador]
      Treinamento --> Extra
  
```

© Prof. Emilio Del Moral Hernandez

152

## Exemplo de modelagem / reconhecimento automático de padrões ... (tese de Liselene / Prof Miguel)

154

defesa08Abr2011\_Liselene.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas defesa08Abr2011\_L... x Fazer logon

22 / 35 63,6%

### Extração no domínio temporal

- \* Energia de curto Prazo

$$E_n = \sum_{m=n}^{n+M} [x(m)w(n-m)]^2$$

- \* Taxa de Cruzamento por zero

$$Z_n = \sum_{m=n}^{n+M} |\text{sgn}[x(m)] - \text{sgn}[x(m-1)]| w(n-m)$$

© Prof. Emilio Del Moral Hernandez

154

## Exemplo de modelagem / reconhecimento automático de padrões ... (tese de Liselene / Prof Miguel)

155

defesa08Abr2011\_Liselene.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas defesa08Abr2011\_L... x Fazer logon

23 / 35 63,6%

### Extração no domínio espectral

- \* Centróide Espectral (Ce)
- \* Largura de Espectro (Le)
- \* Fluxo Espectral
- \* Ponto de Roll-off (Pro)
- \* Taxa de Espalhamento

$$Fe = \sum_{k=1}^M [X(k) - X(m-1)]^2$$

$$Te = \sqrt{\frac{1}{K-1} \sum_{k=1}^K [X(k) - \mu_x]^2}$$

© Prof. Emilio Del Moral Hernandez

155

156

defesa08Abr2011\_Liseline.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas defesa08Abr2011\_L... x Fazer login

30 / 35 63.6% Compartilhar

## Estatística\_M geral

Parâmetro característico	original	Pré-ênfase 1	Pré-ênfase 2
Energia de curto prazo	0.22186	0.10927	0.33554
Taxa de cruzamento por zero	0.21189	0.70758	0.82757
Centridade espectral	0.80933	0.80933	0.79398
Largura de espectro	0.83349	0.88455	0.33555
Fluxo espectral	0.89947	0.57221	0.45769
Ponto de roll-off	0.25491	0.78911	0.66372
Taxa de espalhamento	0.39558	0.17937	0.35939
Modelo AR ordem=10			
Dist. máx. Itakura-AR	0.09678	0.24098	0.34357
Dist. méd. Itakura-AR	0.076167	0.23716	0.38817
Dist. máx. espectral-AR	0.006084	0.4213	0.15637
Dist. méd. espectral-AR	0.11491	0.43526	0.48226
Modelo PLP ordem=2			
Dist. máx. Itakura-PLP	0.24388	0.10265	0.13351
Dist. méd. Itakura-PLP	0.1826	0.15935	0.083996
Dist. máx. espectral-PLP	0.33282	0.197	0.20662
Dist. méd. espectral-PLP	0.21759	0.21076	0.072005

08:05 segunda-feira 15/10/2018

© Prof. Emilio Del Moral Hernandez

156

157

defesa08Abr2011\_Liseline.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas defesa08Abr2011\_L... x Fazer login

31 / 35 63.6% Compartilhar

## Resultado da classificação Individual

Parâmetro Característico	Sinal Original (s)	Sinal pré-ênfase 1 (s)	Sinal pré-ênfase 2 (s)
Energia de curto prazo	64.8936	64.8936	64.8936
Taxa de cruzamento por zero	64.8936	85.1094	87.234
Centridade espectral	77.6596	86.3697	86.7702
Largura de espectro	89.3617	87.234	91.4894
Fluxo espectral	88.2979	87.234	78.7234
Ponto de roll-off	86.8511	86.7702	87.234
Taxa de espalhamento	68.8551	64.8936	69.1489
Dist. máx. Itakura AR (ordem=10)	72.3404	64.8936	81.9787
Dist. méd. Itakura AR (ordem=10)	71.2766	64.8936	84.0426
Dist. máx. espectral AR (ordem=10)	64.8936	71.2766	69.1489
Dist. méd. espectral AR (ordem=10)	67.7021	64.8936	81.9149
Dist. máx. Itakura PLP (ordem=2)	64.8936	71.2766	68.8551
Dist. méd. Itakura PLP (ordem=2)	64.8936	67.0213	65.9574
Dist. máx. espectral PLP (ordem=2)	63.8198	68.0851	67.0213
Dist. méd. espectral PLP (ordem=2)	63.8398	65.9574	69.1489

08:06 segunda-feira 15/10/2018

© Prof. Emilio Del Moral Hernandez

157

158

defesa08Abr2011\_Liselene.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas defesa08Abr2011\_L... x

Fazer login

32 / 35 63.6%

Compartilhar

## Resultado do classificação em grupo

Parâmetros característicos(1)	Acuracidade(1)	Sensibilidade(1)	Especificidade(1)
1,2,3,4,2	95,7447	93,9394	96,7213
1,2,3,4,6,7	95,7447	93,9394	96,7213
1,2,3,4,8	95,7447	93,9394	96,7213
1,2,3,4,5	94,6809	93,9394	95,082
1,2,3,13	95,7447	93,9394	96,7213
1,2,3,12	95,7447	93,9394	96,7213
1,2,3,11	95,7447	93,9394	96,7213
1,2,3,10	95,7447	93,9394	96,7213
1,2,3,9	95,7447	93,9394	96,7213
1,2,3,8	95,7447	93,9394	96,7213
1,2,3,4,13	96,8085	93,9394	98,3607
1,2,3,4,12,13	95,7447	90,9091	93,3607
1,2,3,4,12	96,8085	93,9394	98,3607
1,2,3,4,11	96,8085	93,9394	98,3607
1,2,3,4,10,11	94,6809	87,8788	93,3607
1,2,3,4,10	96,8085	93,9394	98,3607
1,2,3,4,8,9	95,7447	93,9394	96,7213

- 1-Centróide espectral
- 2-Largura de espectro
- 3-Fluxo espectral
- 4-Ponto de roll-off
- 5-Taxa de espalhamento
- 6-Dist. máx. Itakura AR
- 7-Dist. méd. Itakura AR
- 8-Dist. máx. espectral AR
- 9-Dist. méd. espectral AR
- 10-Dist. máx. Itakura PLP
- 11-Dist. méd. Itakura PLP
- 12-Dist. máx. espectral PLP
- 13-Dist. méd. espectral PLP

© Prof. Emilio Del Moral Hernandez

158

### Alguns dos usos do conceito de conjunto de validação (adicional aos conjuntos de treino e teste):

- *Seleção de complexidade do modelo neural para limitação de sobreaprendizado*
- *Ativação do early stop no aprendizado (Matlab): critério de parada adicional no processo de refinamento de pesos sinápticos*
- *Balizador no processo de seleção de estratégias de pré-processamento / extração de medidas X alternativos*
- *... etc*

recordando

+ *Entendendo os fundamentos da análise tempo frequência (uma classe de extratores importante)*

162


*Wavelets*

© Prof. Emilio Del Moral Hernandez

162

## O conceito de wavelets / ondículas / “ondinhas” / ondas localizadas

163



*Uma onda matriz típica*

© Prof. Emilio Del Moral Hernandez

163

## Amostras de slides em análise wavelet, dos Profs da UCM - Madrid, colaboradores no nosso curso de pós PSI5880

164

V1-Parte de Slides de pósgrad PSI5880\_PDF4 em Wavelets - 2010 - Rede\_AIASYB2.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas V1-Parte de Slides ... x Fazer logon

### Scaling

$f_1(t) = \psi(t)$

$s = 1/a$

$a = 2$

$f_2(t) = \psi(2t)$

A low scale compresses the signal  $\Rightarrow$  Fast changing  $\Rightarrow$  High frequencies

$a = 1/2$

$f_3(t) = \psi(t/2)$

A high scale stretches the signal  $\Rightarrow$  Slow changing  $\Rightarrow$  Low frequencies

$f_1(1) = f_2(0.5) = f_3(2)$

© Prof. Emilio Del Moral Hernandez

01:03  
04/12/2017

164

Amostras de slides em análise wavelet, dos Profs da UCM - Madrid, colaboradores no nosso curso de pós PSI5880

165

V1-Parte de Slides de pósgrad PSI5880\_PDF4 em Wavelets - 2010 - Rede\_AIASYB2.pdf - Adobe Acrobat Reader DC

Arquivo Editar Visualizar Janela Ajuda

Início Ferramentas V1-Parte de Slides ... x Fazer login

### Shifting

Si  $d=5$ ,  $f_1(0) = f_2(5) = f_3(-5)$

© Prof. Emilio Del Moral Hernandez

165

## A análise

168

coeficientes wavelet

deslocamento

$$W(a, b) = \int_{-\infty}^{\infty} f(t) \frac{1}{\sqrt{|a|}} \psi^* \left( \frac{t-b}{a} \right) dt.$$

sinal de tempo sob análise

onda mãe sem escalamento ou atraso

escalamento

+ detalhes em <https://pt.wikipedia.org/wiki/Wavelet>

© Prof. Emilio Del Moral Hernandez

168



## A síntese a partir dos coeficientes wavelet

169

$$f(t) = \frac{1}{C} \iint_{-\infty}^{\infty} \frac{1}{|a|^2} W(a, b) \psi_{a,b}(t) da db,$$

↑ sinal de tempo sintetizado

coeficientes wavelet

↑ onda mãe deslocada de "b" e escalada de "a"

+ detalhes em <https://pt.wikipedia.org/wiki/Wavelet>

© Prof. Emilio Del Moral Hernandez

169

## A análise em wavelets e a síntese

170

$$W(a, b) = \int_{-\infty}^{\infty} f(t) \frac{1}{\sqrt{|a|}} \psi^* \left( \frac{t - b}{a} \right) dt.$$
$$f(t) = \frac{1}{C} \iint_{-\infty}^{\infty} \frac{1}{|a|^2} W(a, b) \psi_{a,b}(t) da db,$$

+ detalhes em <https://pt.wikipedia.org/wiki/Wavelet>

© Prof. Emilio Del Moral Hernandez

170

+ *Entendendo os fundamentos da Análise de Componentes (estatisticamente) Principais*

*PCA – Principal Component Analysis*

*(uma técnica de extração importante)*



## REFERÊNCIAS

- [1] CHELLAPPA, Rama; WILSON, Charles; SIROHEY, Saad. *Human and Machine Recognition of Faces: A Survey*. Proceedings of the IEEE, vol 83 no.5, May 1995.
- [2] KITANI, E.C., THOMAZ, C.E. "Um Tutorial sobre Análise de Componentes Principais para Reconhecimento Automático de Faces", Relatório Técnico, Depto Engenharia Elétrica, FEI-SP, 01/2006.
- [3] TURK, Matthew; PENTLAND, Alex. *Eigenfaces for Recognition*. Journal of Cognitive Science, vol. 3 no 1, MIT 1991.
- [4] ZHAO, Weny; CHELLAPPA, Rama; KRISHNASWAMY, Arvindli. *Discriminant Analysis of Principal Components for Face Recognition*. IEEE, 1998.
- [5] FUKUNAGA, Keinosuke, "Introduction to Statistical Pattern Recognition", 2ª ed., Boston, MA: Academic Press, 1990.
- [6] OSUNA, Ricardo Gutierrez, "Principal Components Analysis, Lecture Notes" 9, Texas A&M University, Texas, 2004, disponível em [www.courses-cs.tamu.edu/rgutier/cs790-w02](http://www.courses-cs.tamu.edu/rgutier/cs790-w02), acessado em 20/12/2005.
- [7] SIROVICH, L. KIRBY, M, "Low-dimensional Procedure for the Characterization of Human Faces", Journal of the Optical Society of America, vol. 4, pp 519-524, 1987.
- [8] THOMAZ, Carlos Eduardo, "Estudo de Classificadores para Reconhecimento Automático de Faces", Tese de Mestrado, 104 pg., PUC RJ, 1999.



- [9] JOLLIFE, I.T., "*Principal Components Analysis*", Springer-Verlag, London. UK, 2002.
- [10] PEARSON, K. "*On lines and planes of closest fit to system of point in space*", *Philosophical Magazine*, 2: pp 550-572, 1901, disponível em <http://pbil.univ-lyon1.fr/R/pearson190.pdf>, acessado em 06/05/2006.
- [11] BARTLETT, M. S., et al., "*Face Recognition by Independent Component Analysis*", *IEEE Transactions on Neural Networks*, vol 13, no. 6, November, 2002.
- [12] JAIN, Anil, et al. "*Biometrics: A Grand Challenge*", Presentation, disponível em <http://biometrics.cse.msu.edu>, acessado em 10/10/2005.